

文章编号:1671-6833(2026)03-0108-09

融合多信息的图卷积实体对齐方法

徐贞顺^{1,2}, 张文豪^{1,2}, 王振彪^{1,2}, 唐增金^{1,2}, 赵泽宇^{1,2}, 苏梦瑶^{1,2}

(1. 北方民族大学 计算机科学与工程学院, 宁夏 银川 750021; 2. 北方民族大学 图像图形智能处理国家民委重点实验室, 宁夏 银川 750021)

摘要: 由于不同知识图谱在实体表示、关系定义和语义结构等方面的异质性, 在图谱的结构性差异和信息缺失的情况下, 仅依赖图结构难以有效提高对齐质量。为此, 提出了一种融合多信息的图卷积实体对齐方法。首先, 改进的 PageRank 算法用于筛选三元组, 缓解知识图谱结构差异带来的影响; 其次, 通过图卷积网络学习实体和属性的嵌入表示, 并利用这些表示迭代更新实体间的关系; 最后, 基于 PBAB 方法整合文本描述信息, 与图结构信息加权融合, 从而提升实体对齐的效果。实验在 DBP15K 数据集上开展, 评估了所提方法与基准方法在实体对齐任务中的表现。实验结果表明: 所提方法在 Hits@1 指标上相较于最优基准方法提升了约 3%, 其他评价指标也均有相应的提升。

关键词: 知识图谱; 图卷积网络; 实体对齐; 图注意力网络; 预训练语言模型

中图分类号: TP391 **文献标志码:** A **doi:** 10.13705/j.issn.1671-6833.2026.03.010

知识图谱是一种通过图结构表示实体及其关系的语义网络, 用于存储和组织丰富的知识信息^[1]。实体对齐^[2] (entity alignment, EA) 是知识图谱融合中的关键任务, 其主要目标是识别并匹配在不同知识图谱中表示相同概念或实体的元素, 从而构建不同知识图谱之间的连接。早期的实体对齐方法大多集中于基于字符串匹配的方法、基于规则的方法以及基于语义相似度的方法等^[3]。

近年来, 基于表示学习的实体对齐模型技术应运而生。这类技术旨在捕获实体之间的语义关联关系, 提高对齐的准确性和鲁棒性。基于翻译的实体对齐方法的核心思想是将实体和关系嵌入为向量, 通过向量加法或转换来实现映射, TransE^[4] 是一种经典的知识图谱嵌入方法, 因其在实体对齐任务中的优越表现, 得到了广泛应用。基于 TransE 的思想, 许多更具高效性和精度的实体对齐模型相继被提出, 例如, MTransE^[5]、IPTransE^[6]、JAPE^[7]、BootEA^[8] 和 MultiKE^[9] 等。图卷积网络 (graph convolutional network, GCN) 通过聚合邻域信息来提升表示能力的特性, 使其成为实体对齐任务中的重要工具。GCN-Align^[10] 首次将图卷积应用于实体对齐任务,

相比于传统方法, GCN-Align 具有更强的表达能力和泛化能力, 能够有效应对异构数据集以及实体演化等复杂问题。AliNet^[11] 通过引入自适应注意力机制, 进一步提升了实体对齐的性能。RDGCN^[12] 和 RNM^[13] 通过引入预训练的词向量来初始化模型, 从而将实体名称的语义信息有效地融入实体表示中。高速图卷积网络能够更有效地传递信息、缓解梯度消失问题, HGCN^[14] 通过高速门机制, 在每个图卷积网络层中学习不同程度的信息传递和过滤, 以平衡来自中心实体和邻域聚合的信息。

目前, 大多数实体对齐方法侧重图结构信息, 忽略了文本信息的潜在价值。因此, 本文提出了一种融合多信息的图卷积实体对齐方法 (multiple information for graph convolutional network entity alignment, MIGCNEA), 旨在解决知识图谱的异质性问题, 并充分利用图结构和文本信息的互补性。本研究的主要贡献如下: ① 构建了基于改进 PageRank 算法的三元组筛选模块, 通过计算知识图谱及其关系对偶图的重要性, 筛选过滤无效三元组, 缓解不同知识图谱结构性差异。② 利用高速图卷积网络学习实体和属性的嵌入表示, 进而利用实体属性信息学习

收稿日期: 2025-12-21; 修订日期: 2026-01-16

基金项目: 宁夏重点研发计划 (重点) 项目 (2023BDE02001); 银川市校企联合创新项目 (2022XQZD009)

作者简介: 徐贞顺 (1977—), 女, 宁夏银川人, 北方民族大学讲师, 博士, 主要从事数据挖掘与知识发现研究, E-mail: seojain@qq.com。

引用本文: 徐贞顺, 张文豪, 王振彪, 等. 融合多信息的图卷积实体对齐方法 [J]. 郑州大学学报 (工学版), 2026, 47(3): 108-116. (XU Z S, ZHANG W H, WANG Z B, et al. Multiple information graph convolutional network entity alignment method [J]. Journal of Zhengzhou University (Engineering Science), 2026, 47(3): 108-116.)

关系信息,并通过关系迭代更新实体信息,缓解知识图谱异质性问题,提高了方法的表达能力和泛化能力。③提出了一种基于微调 BERT 的 PBAB (pairwise BERT attention Bi-LSTM) 方法,整合实体文本描述信息,并将基于图的模块和基于文本的模块进行加权融合,综合利用文本信息和图结构信息,以提高实体对齐的准确性和泛化能力。

1 问题定义

知识图谱视为 3 个基本部分组成的结构:实体集 E 、关系集 R 以及三元组集合 T ,即 $KG = (E, R, T)$ 。在这个结构中,实体集 E 包含了图谱中的所有实体,关系集 R 则定义了实体之间可能的各种关系。

假设有两个知识图谱 $KG1 = (E_1, R_1, T_1)$ 和 $KG2 = (E_2, R_2, T_2)$,其中 $KG1$ 和 $KG2$ 包含各自的一组实体集合 E_1 和 E_2 ,并描述了两者之间的关系和属性。实体对齐问题的核心任务,是识别这两个知识图谱中所描述的同一体在不同图谱中的对应节点。实体对齐问题旨在找到一个映射函数,如式 (1) 所示。

$$f: E_1 \rightarrow E_2. \tag{1}$$

式中: f 为映射函数,将 $KG1$ 中的实体映射到 $KG2$ 中的对应实体。

2 MIGCNEA 方法

本文提出了融合多信息的图卷积实体对齐方法,如图 1 所示。该方法主要包含 3 个模块,分别是三元组筛选模块、图结构信息表示模块以及文本信息表示模块。

2.1 三元组筛选模块

知识图谱的结构特征以三元组形式表示,不同图谱间三元组数量差异可能影响实体对齐任务。为解决这一问题,本文提出了一种三元组筛选模块,通过对三元组重要性评分,去除无效三元组,从而提高实体对齐的准确性和效率。

在知识图谱中,PageRank 算法^[15]可以用来评估图谱中实体的重要性。通过迭代计算每个实体的重要性得分,考虑到实体之间的链接关系,从而识别知识图谱中的关键实体。其计算公式为

$$PR(a)_{i+1} = (1 - d) + d \sum_{i=0}^n \frac{PR(T_i)_i}{L(T_i)}. \tag{2}$$

式中: a 为计算 PageRank 的节点; T_i 为引用节点, d 为阻尼系数,表示节点被引用的概率,一般取 0.85; $L(T_i)$ 为节点 T_i 的出链。

在图结构中,节点的重要性与其连接数不成成正比。特征向量中心度算法通过考虑节点的连接质量和重要性,识别出在网络中具有更高影响力的节点,超越了仅依赖连接数的度数。在 PageRank 算法的基础上,融合特征值中心性算法,设 C_i 为特征中心性,对齐加权 $C_i = \mu_i \lambda_i$,用权重系数 μ_i 来调整特征值中心性,更好地地区分链路网络中节点的重要性,计算如式 (3) 所示。

$$PR(a)_{i+1} = (1 - d) + d \sum_{i=0}^n \frac{C_i PR(T_i)_i}{L(T_i)}. \tag{3}$$

PageRank 算法本质上是基于图的中心性度量方法,通过节点的“入链”数量和权重评估节点重要性。改进 PageRank 结合特征值中心性等加权机制,精准地评估节点重要性,特别是核心实体。此外,筛

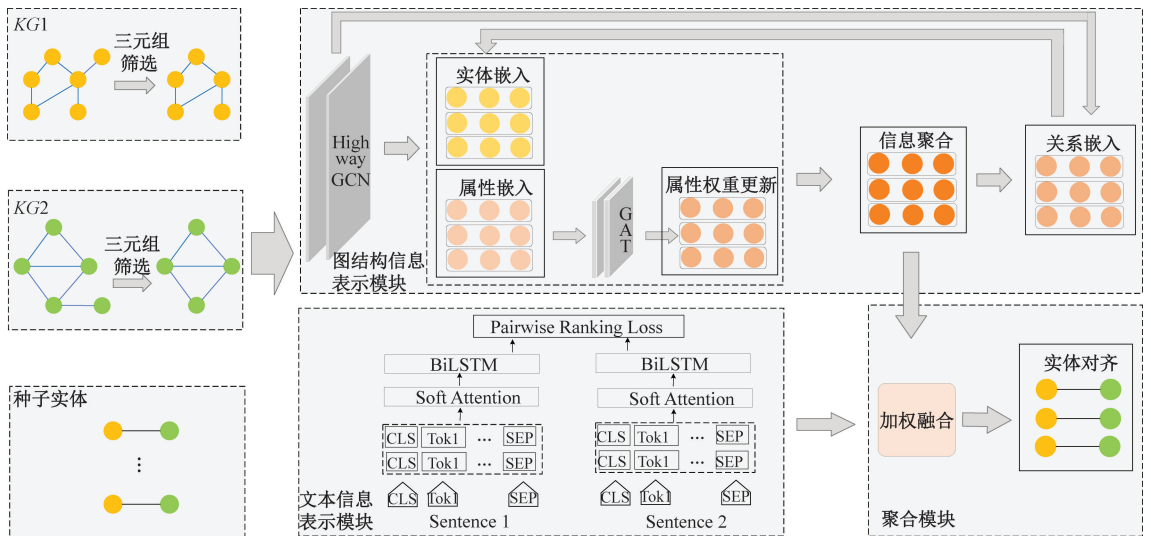


图 1 MIGCNEA 方法框架
Figure 1 MIGCNEA method framework

选模块通过加权机制处理异构信息,避免评估失真,确保知识图谱对齐和融合过程中的精度。三元组筛选模块主要包括三部分:关系对偶图、PageRank 值计算和得分函数计算,模块结构如图 2 所示。

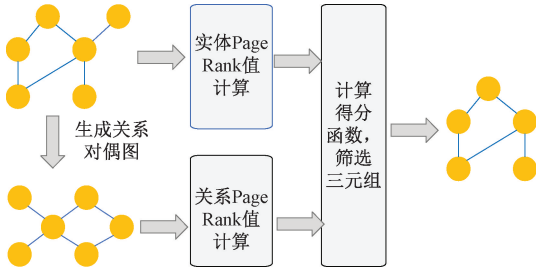


图 2 基于 PageRank 的三元组筛选模块

Figure 2 Triple filtering module based on PageRank

首先,构建以关系为点的关系对偶图。在一个图中,节点表示实体,边表示实体之间的关系;而在关系对偶图中,节点表示关系,边表示关系之间的连接。然后,通过公式(3)计算实体和关系的 PageRank 值。最后,通过三元组评分公式(4)计算三元组得分,筛选三元组,基于三元组评分设置阈值 δ ,保留 $\text{score}(h, r, t) > \delta$ 的三元组。

$$\text{score}(h, r, t) = \alpha[\text{PR}(h) + \text{PR}(t)] + \beta\text{PR}(r). \quad (4)$$

该模块通过引入改进的 PageRank 算法和特征中心值策略,有效提高了三元组的筛选精度,增强了知识图谱的整体质量。通过这一方法,能够更好地处理图中的异质性问题,从而提升知识图谱的可靠性和实用性。

2.2 图结构信息表示模块

本节提出的高速图卷积网络信息表示模块,包括实体、属性和关系嵌入,利用迭代更新机制优化嵌入,充分利用知识图谱中的结构信息。通过深度学习和多层次更新,逐步精炼实体和关系的表示,增强了知识图谱在实体对齐任务中的表达能力。

2.2.1 实体嵌入

图卷积网络是一种用于处理图数据的深度学习模型,基于邻居节点的信息传播来更新每个节点的表示,类似于在图上进行卷积操作。通过多层的 GCN 堆叠,可以逐步聚合更远的节点信息,并且学习到更高级的表示。对于每一层 GCN 的输入 $\mathbf{H}^{(l)}$,输出可以表示为

$$\mathbf{H}^{l+1} = \sigma\left(\hat{\mathbf{D}} - \frac{1}{2}\hat{\mathbf{A}}\hat{\mathbf{D}} - \frac{1}{2}\mathbf{H}^l\mathbf{W}^l\right). \quad (5)$$

式中: $\hat{\mathbf{A}}$ 为邻接矩阵 \mathbf{A} 与单位矩阵 \mathbf{I} 的和; $\hat{\mathbf{D}}$ 是对应于 $\hat{\mathbf{A}}$ 的度矩阵,对每个节点的邻居信息进行归一化。权重矩阵 $\mathbf{W}^l \in \mathbf{R}^{d^l \times d^{l+1}}$ 表示第 l 层与第 $l+1$ 层之间的线性变换,而 σ 则是 ReLU 激活函数,用来引

入非线性特性,使得模型能够更好地学习复杂的图结构。

Highway GCN 结合了高速公路网络的门控机制,控制信息流动以学习深层次表示。它在每层更新中调节邻居节点特征与原始特征的传递比例。本文采用带高速公路网络的双层 GCN 进行信息嵌入,使用转换门和保留门分别控制信息流入和绕过当前层。

$$\mathbf{H}_e^{l+1} = \mathbf{T}(\mathbf{H}_e^l) \cdot \mathbf{H}_e^{l+1} + \mathbf{C}(\mathbf{H}_e^l) \cdot \mathbf{H}_e^l. \quad (6)$$

式中: \mathbf{T} 为转换门,其主要任务是控制当前层信息的转换与更新,决定了从上一层传递的信息应当如何进行变化或调整; \mathbf{C} 为携带门,其定义为 $\mathbf{C} = 1 - \mathbf{T}$,负责保留上一层的信息流动,并通过 \mathbf{C} 来控制哪些信息需要被传递到当前层。

2.2.2 属性嵌入

知识图谱中除了包含实体信息外,还包含许多属性信息,属性信息可以作为辅助信息,帮助提高实体对齐的准确性。同样,本文使用 Highway GCN 学习实体的属性嵌入。属性嵌入的图卷积计算过程如式(7)、式(8)所示。

$$\mathbf{H}_a^{l+1} = \sigma\left(\hat{\mathbf{D}}^{-\frac{1}{2}}\hat{\mathbf{A}}\hat{\mathbf{D}} - \frac{1}{2}\mathbf{H}_a^l\mathbf{W}_a^l\right); \quad (7)$$

$$\mathbf{H}_a^{l+1} = \mathbf{T}(\mathbf{H}_a^l) \cdot \mathbf{H}_a^{l+1} + \mathbf{C}(\mathbf{H}_a^l) \cdot \mathbf{H}_a^l. \quad (8)$$

式中: \mathbf{H}_a^l 表示第 l 层属性嵌入的输入; \mathbf{H}_a^{l+1} 表示第 l 层 GCN 属性嵌入的输出; \mathbf{W}_a^l 为第 l 层的属性权值矩阵。

在实际的知识图谱中,每个实体通常具有多个属性,而不同的属性对实体的影响程度也有所不同。图注意力网络(graph attention network, GAT)是一种能够有效处理图结构数据的模型,具有自动关注不同节点和属性重要性的能力,允许节点在信息传递过程中根据邻居节点的重要性动态地分配注意力权重,从而更有效地聚合邻居节点的信息。本文采用属性更新模块更新属性权重。该模块赋予属性初始权重,并在传播过程中利用 GAT 更新属性权重。其传播过程如图 3 所示。




图 3 GAT 传播过程

Figure 3 The GAT propagation process

GAT 每个节点特征的注意力值计算如式(9)、式(10)、式(11)所示。

$$e_{ij} = a[\mathbf{W}\mathbf{h}_i \parallel \mathbf{W}\mathbf{h}_j], j \in N_i; \quad (9)$$

$$a_{ij} = \frac{\exp(\text{LeakyReLU}(e_{ij}))}{\sum_{k \in N_i} \exp(\text{LeakyReLU}(e_{ik}))}; \quad (10)$$

$$\mathbf{h}'_i = \sigma \sum_{j \in N_i} (a_{ij} \mathbf{W}\mathbf{h}_j). \quad (11)$$

式中: \mathbf{W} 为特征权重矩阵; $j \in N_i$ 表示遍历 i 相邻的所有节点 j ; a_{ij} 为注意力相关系数; σ 为非线性激活函数 LeakyReLU; \mathbf{h}'_i 表示顶点 i 的新特征。

在结构嵌入和属性嵌入后,采用向量融合的方法融合了实体嵌入 \mathbf{H}_e 和属性嵌入 \mathbf{H}_a 。设 $\text{concat}(\cdot)$ 表示向量融合; α 表示权重参数, $\mathbf{h}_e(\cdot)$ 和 $\mathbf{h}_a(\cdot)$ 分别表示实体嵌入和属性嵌入的特征向量; f_e 和 f_a 表示维度; β 表示平衡参数,结构信息和属性信息的聚合如式(12)所示,相似度距离计算如式(13)、式(14)所示。

$$\mathbf{H}_{ea} = \text{concat}(\alpha \mathbf{H}_e, (1 - \alpha) \mathbf{H}_a); \quad (12)$$

$$D(e_i, e_j) = \beta \frac{f(\mathbf{h}_e(e_i), \mathbf{h}_e(e_j))}{f_e} + (1 - \beta) \frac{f(\mathbf{h}_a(e_i), \mathbf{h}_a(e_j))}{f_a}; \quad (13)$$

$$f(\mathbf{x}, \mathbf{y}) = \|\mathbf{x} - \mathbf{y}\|. \quad (14)$$

边界损失函数如公式(15)所示。

$$L_e = \sum_{(e_i, e_j \in S)} \sum_{(e'_i, e'_j \in S')} [f(\mathbf{h}_e(e_i), \mathbf{h}_e(e_j)) - f(\mathbf{h}_e(e'_i), \mathbf{h}_e(e'_j)) + \gamma_e]. \quad (15)$$

2.2.3 关系嵌入

在知识图谱中,信息通过三元组 $(\mathbf{h}, \mathbf{r}, \mathbf{t})$ 表示。通过实体对齐,可以学习和迁移关系信息,提升关系对齐的准确性。本文通过学习实体信息来优化关系信息,并利用关系信息迭代更新实体信息。同时,为进一步探索基于三元组的关系信息,本文引入了一个正则化器进行优化。

$$\Omega = \sum_{\mathbf{h}, \mathbf{r}, \mathbf{t} \in T_1 \cup T_2} \|\mathbf{h} + \mathbf{W}\mathbf{r} - \mathbf{t}\|. \quad (16)$$

式中: $T_1 \cup T_2$ 表示两个知识图谱中的三元组的并集; \mathbf{W} 则表示学习模型中的参数。

通过多次迭代更新实体间的关系传播,优化实体的嵌入表示。关系嵌入向量与实体交互调整实体嵌入,捕捉语义和结构信息。关系迭代更新精细化嵌入表示,提高跨图谱对齐准确性,并增强模型在多任务中的性能。为了在同一框架中同时优化实体和关系的嵌入表示,本文提出了一种联合学习方法,通过设计一个综合目标函数来共同训练实体嵌入和关系嵌入。该目标函数如公式(17)所示。

$$L = L_e + \lambda \Omega. \quad (17)$$

式中: L_e 表示实体对齐损失,衡量实体嵌入在不同

知识图谱之间的一致性和准确性; λ 为一个超参数,作用是平衡两个损失项的相对重要性,通过适当调整 λ ,可以确保模型在对齐精度和泛化能力之间达到良好的平衡。

2.3 文本信息表示模块

本文提出的 PBAB 方法,基于微调的预训练语言模型、融合注意力机制和 Bi-LSTM 模型,有效捕捉文本细粒度语义差异。该方法深入理解实体及其与周围词语的关系,提升实体对齐准确性,尤其在实体高相似度且文本信息丰富时表现优异。

目前许多知识图谱实体对齐的研究主要集中在图结构的嵌入上,而忽略了文本信息的嵌入,文本信息可以为实体对齐提供宝贵的辅助。近年来,双向编码器表示(BERT)^[16]通过基于语言建模的大规模预训练,在自然语言处理各领域取得了显著进展。在多语言环境中,BERT 的核心思想是将来自不同语言的单词或句子映射到统一的语义空间中。基于此,本文提出 PBAB 方法,如图 4 所示。组合方法 PBAB 的网络框图由 PairwiseBERT 层、Attention 层和 BiLSTM 层组成。

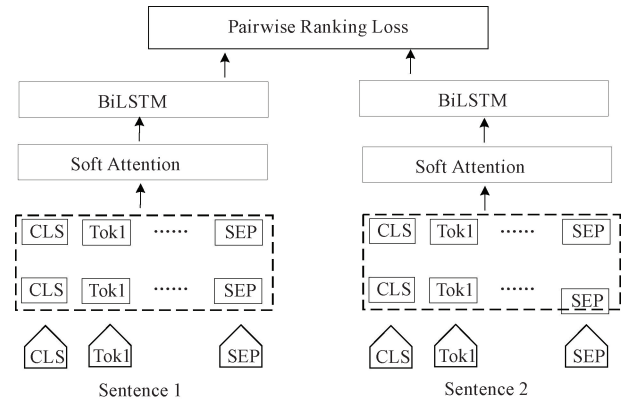


图 4 PBAB 方法框架

Figure 4 PBAB method framework

(1) PairwiseBERT 层: 该方法利用预训练的 BERT 模型,将实体描述转换为高质量文本嵌入,捕捉语法和语义特征。其双向上下文建模和自注意力机制使其在多语言环境中表现优异,具有更好的适应性和扩展性。通过微调 BERT,提升实体对齐准确性,特别在多语言环境下具有更好的适应性和扩展性。

(2) Attention 层: Attention 机制通过动态加权词语,灵活捕捉文本关联信息,提升语义理解能力。它处理上下文依赖性,使词在不同情境下重要性不同,并有效应对长程依赖。Soft Attention 通过加权平均调整信息重要性,广泛应用于深度学习模型中,增强长程依赖捕捉,提升性能。

(3) Bi-LSTM 层: LSTM 是一种特殊的 RNN, 能够学习长期依赖关系。LSTM 通过引入门机制(输入门、遗忘门和输出门)来克服传统 RNN 在处理长序列时的梯度消失和梯度爆炸问题。Bi-LSTM 层对实体描述的文本嵌入序列进行建模, 以获取更丰富的语义表示。通过双向的设计, Bi-LSTM 能够同时考虑文本序列的过去和未来信息, 提高了方法对文本序列的理解能力。

2.4 聚合模块

知识图谱实体对齐聚模块通过识别、对齐和聚合不同来源的实体信息, 提升图谱的准确性和全面性, 消除数据孤岛, 实现知识共享与重用。本文将 PBAB 学习到的文本嵌入记为 H_B , 图嵌入记为 H_C , 将两个模块通过加权连接聚合, 聚合函数如式(18)所示。

$$H = \gamma H_C \oplus (1 - \gamma) H_B. \quad (18)$$

式中: H_C 表示由方法学习的图嵌入; H_B 为由方法学习的文本嵌入; γ 为平衡图嵌入和文本嵌入的平衡因子。

3 实验结果与分析

3.1 数据集和实验环境

为评估 MIGCNEA 实体对齐方法的性能, 本文使用 DBPedia 数据集下的不同语言版本构建的实体对齐数据集 DBP15K, 如表 1 所示。该数据集包含 3 个子版本的数据集: DBP15K-ZH-EN(中文-英语)、DBP15K-JA-EN(日语-英语)和 DBP15K-FR-EN(法语-英语)。

表 1 DBP15K 数据集信息统计

Table 1 Statistics of DBP15K dataset

数据集	实体数	关系数	三元组数
DBP15K-ZH-EN	66 469	2 830	153 929
	98 125	2 317	237 674
DBP15K-JA-EN	65 744	2 043	164 373
	95 680	2 096	233 319
DBP15K-FR-EN	66 858	1 379	192 191
	95 680	2 209	278 590

本文提出的 MIGCNEA 方法采用深度学习框架 TensorFlow 构建并在 12 vCPU Intel(R) Xeon(R) Platinum 8352V CPU @ 2.10GHz 和 RTX 4090(24 GB) GPU 上训练。本方法是基于图神经网络的实体对齐方法, 每批次训练样本的大小为 20, 节点嵌入维数为 300, Highway GCN 层数为 2, 训练轮次为 60, 学习率为 0.001, 正则化参数采用 L2 正则, γ 值为 0.9。按照惯例, 将数据集的 30% 作为训练数据, 剩下的 70% 用作测试数据, 观察在设置不同数据集情

况下, 60 轮训练迭代过程中 MIGCNEA 方法损失函数的收敛情况。

为了深入探讨 MIGCNEA 方法的收敛速度, 本文对其在 3 个公共数据集上的实验轮数进行了细致的对比分析, 并系统地比较了损失率的变化情况, 如图 5 所示。实验结果表明, MIGCNEA 方法在 60 轮内将损失率降至最低, 展示了其高效性和快速适应数据特征的能力。前 50 轮中, 方法通过参数调整学习到关键特征, 损失率显著下降, 最终在第 60 轮达到最低, 验证了其良好的拟合效果和通用性。




图 5 MIGCNEA 在不同数据集下的训练损失曲线

Figure 5 MIGCNEA training loss for different datasets

3.2 评价指标

本文采用 Hits@ k 和 MRR 作为实体对齐效果的评价指标。其中, Hits@ k 表示在模型生成的候选列表中, 有多少比例的正确实体或关系排在前 k 个位, 其计算如式(19)所示。Hits@ k 越高, 表示模型对齐的效果越好。按照惯例, 本文 k 取值 1 和 10。

$$\text{Hits}@k = \frac{1}{|S|} \sum_{i=1}^{|S|} \mathbb{I}(\text{rank}_i \leq k). \quad (19)$$

式中: $\mathbb{I}(\cdot)$ 为 indicator 函数, 满足条件时为 1, 反之为 0。

MRR 指平均倒数排名, 通过计算正确实体或关系的倒数排名的平均值评估补全模型的性能, 其计算如式(20)所示, MRR 越高, 结果越优。

$$MRR = \frac{1}{|S|} \sum_{i=1}^{|S|} \frac{1}{\text{rank}_i}. \quad (20)$$

3.3 对比实验

为验证 MIGCNEA 方法与其他方法在同等条件下的优越性, 设置对比实验, 对比方法包括基于嵌入的模型: MTransE^[5], JAPE^[7], BootEA^[8], ESEA^[17] 以及基于神经网络的模型: GCN-Align^[10], AliNet^[11], RDGCN^[12], HGCN^[14], MHGCN^[18], AWUN^[19], RNM^[13], AR-Align^[20], RAGA^[21], 如表 2 所示。

3.4 实验结果

由表 2 可知, 其在实体对齐任务中显著优于 13 种基线方法。在 Hits@1 指标上始终超过 90%, 在

Hits@10 上均高于 99%,且 *MRR* 高于 95%。与 RAGA 方法相比,MIGCNEA 在 3 个数据集上的提升分别为 6.26%,0.71% 和 4.01% (Hits@1),以及 5.19%,1.56% 和 1.61% (Hits@10)。这些结果表明,MIGCNEA 通过有效的三元组筛选模块和嵌入模块,成功缓解了知识图谱的异质性问题。

与传统的知识图谱实体和关系嵌入方法相比,迭代更新机制通过多次修正实体和关系的嵌入,能够捕捉节点间的长程依赖和复杂语义关联。每次迭代优化实体与关系表示,提升了对复杂关系的处理能力。结合文本信息进一步丰富了实体的语义理

解,利用预训练的文本嵌入转化为向量并与图结构数据结合,增强了实体的语义表示能力,从而提高了实体对齐的精度和区分度。

为了更清晰地了解方法在不同评价指标下的表现,如图 6 所示,分析各数据集中 Hits@1 和 Hits@10 的变化情况。结果表明,Hits@1 指标的提升幅度略高于 Hits@10,表明本文提出的方法在潜在实体集合中更加有效地识别出正确实体,从而显著提高了实体对齐任务的命中率。实验结果进一步验证了本方法在实体对齐任务中的有效性,强调了其对知识图谱构建的积极贡献。

表 2 实体对齐实验结果

Table 2 Results of entity alignment experiment

单位: %

方法	DBP15K-ZH-EN			DBP15K-JA-EN			DBP15K-FR-EN		
	Hits@1	Hits@10	<i>MRR</i>	Hits@1	Hits@10	<i>MRR</i>	Hits@1	Hits@10	<i>MRR</i>
MTransE	30.83	61.41	36.4	24.41	55.55	34.9	27.86	57.45	33.6
JAPE	41.18	74.46	49.0	32.39	66.68	47.6	36.25	68.50	43.0
BootEA	61.85	84.52	70.1	63.21	86.54	71.2	66.35	87.69	74.1
ESEA	72.47	86.94	77.5	74.99	87.78	79.5	79.39	90.88	83.4
GCN-Align	39.32	70.12	52.9	40.88	73.34	52.2	39.63	75.92	51.8
AliNet	53.90	82.60	62.8	54.90	83.10	64.5	55.20	85.20	65.6
RDGCN	70.98	85.37	75.6	75.73	88.37	80.1	88.60	95.51	90.1
HGCN	69.28	87.61	74.8	75.26	87.59	79.2	89.02	95.58	91.7
MHGCN	73.55	86.53	78.8	77.53	89.58	82.3	86.83	92.49	90.0
AWUN	75.10	88.30	79.6	80.50	92.40	85.6	92.51	97.63	94.6
RNM	83.40	92.10	87.3	85.64	94.68	84.8	91.50	97.40	93.8
AR-Align	84.80	93.50	87.7	90.00	95.70	91.9	98.50	99.70	98.9
RAGA	87.64	94.30	90.3	94.95	98.00	96.3	94.60	98.29	96.1
MIGCNEA	94.26	99.49	95.8	95.66	99.56	96.5	98.61	99.90	99.0




图 6 实验结果对比

Figure 6 Comparison of experimental results

3.5 消融实验

为了评估 MIGCNEA 方法的性能,本文进行了一系列消融实验,并将结果整理在表 3 中。本文针对三个关键方面进行了分析:①MIGCNEA(-PR)移除了三元组筛选模块;②MIGCNEA(-R)移除了关系嵌入;③MIGCNEA(-B)移除了 PBAB 方法。

从表 3 可见,移除 PBAB 框架后,MIGCNEA 性

能显著下降,验证了该模块的重要性。同时,移除三元组筛选模块和关系嵌入后,结果表明三元组筛选模块提高了实体对齐的准确性。结构信息表示模块通过图结构的迭代更新机制优化实体和关系表示。PBAB 模块将实体对齐转化为文本匹配任务,利用词语位置和上下文信息生成精准嵌入,帮助捕捉细粒度语义信息,提升实体对齐任务的表现。

表3 消融实验结果

Table 3 Results of ablation experiment 单位:%

数据集	方法	Hits@1	Hits@10	MRR
DBP15KZH-EN	MIGCNEA (-PR)	92.08	99.19	95.21
	MIGCNEA (-R)	91.42	99.32	94.66
	MIGCNEA (-B)	87.75	98.13	90.75
	MIGCNEA	94.26	99.49	95.82
DBP15KJA-EN	MIGCNEA (-PR)	95.03	99.26	95.89
	MIGCNEA (-R)	94.91	99.54	95.52
	MIGCNEA (-B)	90.93	98.78	92.51
	MIGCNEA	95.66	99.56	96.56
DBP15KFR-EN	MIGCNEA (-PR)	97.23	99.72	97.56
	MIGCNEA (-R)	96.85	99.66	97.11
	MIGCNEA (-B)	94.28	99.24	96.86
	MIGCNEA	98.61	99.90	99.00

MIGCNEA方法通过三元组筛选模块提高实体对齐准确率,该模块采用改进的PageRank算法筛选低质量或冗余的三元组,优化图结构并减少噪声。结合PageRank和特征加权中心性,评估三元组质量并调整过滤策略,进一步优化对齐。图结构信息表示模块通过嵌入信息学习实体关系,并通过迭代优化更新实体表示,使其语义匹配一致。文本表示模块使用PBAB方法,将实体对齐转化为文本匹配,生成精准嵌入,帮助捕捉细粒度语义,提升对齐效果。

为了深入研究图结构信息与文本信息权重比对方法准确性的影响,本文通过实验研究了图结构信息与文本信息权重比对实体对齐准确性的影响。实验设置了多个 γ 值(图结构信息权重),并逐步调整其值以观察实体对齐效果。实验结果表明,随着 γ 值增大,Hits@1和Hits@10的值逐渐上升,说明增加图结构信息与文本信息的权重比有助于提高实体对齐精度。特别地,当 γ 值为0.9时,Hits@1和Hits@10达到最优,证明该权重配置有效提升了方法性能。




图7 图结构信息和文本信息权重比结果

Figure 7 Weight ratio result of graph structure information and text information

实验结果表明,图结构信息与文本信息的加权融合显著影响方法性能。图结构通过明确的实体连接捕捉基本语义关系,适合关系紧密的实体对齐任务,尤其在结构化语义中表现优越。然而,图结构无法完全处理复杂语境,文本信息则补充了这一不足,增强了模型对上下文的理解。当图结构信息占主导时,方法更注重实体关系,优化了对齐效果。

4 结论

本文提出了一种MIGCNEA方法,用于跨语言知识图谱实体对齐任务。该方法首先通过改进的PageRank算法评估三元组的重要性,筛选出无效三元组,从而缓解不同知识图谱之间的结构差异。为了提高关系嵌入质量,在图结构信息表示模块采用两层Highway GCN进行编码,实现实体和属性嵌入,然后利用实体和属性信息学习嵌入关系信息,并迭代更新实体和关系信息。在文本信息表示模块,利用PBAB方法嵌入文本信息,将图结构信息与文本信息加权融合,更好地利用多方面信息实现知识图谱实体对齐。实验结果表明,该方法在公共数据集上表现出了较好的效果,验证了MIGCNEA方法的有效性。

参考文献:

- [1] 李卫军, 顾建来, 张新勇, 等. 基于关系学习的小样本知识图谱补全模型[J]. 郑州大学学报(工学版), 2024, 45(4): 53-61.
LI W J, GU J L, ZHANG X Y, et al. Relation learning completion model for few-shot knowledge graphs [J]. Journal of Zhengzhou University (Engineering Science), 2024, 45(4): 53-61.
- [2] FANOURAKIS N, EFTHYMIU V, KOTZINOS D, et al. Knowledge graph embedding methods for entity alignment: experimental review [J]. Data Mining and Knowledge Discovery, 2023, 37(5): 2070-2137.
- [3] 庄严, 李国良, 冯建华. 知识库实体对齐技术综述 [J]. 计算机研究与发展, 2016, 53(1): 165-192.
ZHUANG Y, LI G L, FENG J H. A survey on entity alignment of knowledge base [J]. Journal of Computer Research and Development, 2016, 53(1): 165-192.
- [4] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data [C] // NIPS'13: Proceedings of the 26th International Conference on Neural Information Processing Systems-Volume 2, Advances in Neural Information Processing Systems. New York: ACM, 2013: 2787-2795.

- [5] CHEN M H, TIAN Y T, YANG M H, et al. Multilingual knowledge graph embeddings for cross-lingual knowledge alignment[EB/OL]. (2017-05-017) [2025-03-04]. <https://arxiv.org/abs/1611.03954v3>.
- [6] ZHU H, XIE R B, LIU Z Y, et al. Iterative entity alignment via joint knowledge embeddings[C]//Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence (IJCAI-2017). Melbourne: International Joint Conferences on Artificial Intelligence, 2017: 1-7.
- [7] SUN Z Q, HU W, LI C K. Cross-lingual entity alignment via joint attribute-preserving embedding[M]//The Semantic Web-ISWC 2017. Cham: Springer International Publishing, 2017: 628-644.
- [8] SUN Z, HU W, ZHANG Q, et al. Bootstrapping entity alignment with knowledge graph embedding[C]//27th International Joint Conference on Artificial Intelligence and 23rd European Conference on Artificial Intelligence: IJCAI-ECAI 2018. Melbourne: International Joint Conferences on Artificial Intelligence, 2018: 1-7.
- [9] ZHANG Q H, SUN Z Q, HU W, et al. Multi-view knowledge graph embedding for entity alignment[EB/OL]. (2019-06-06) [2025-03-12]. <https://arxiv.org/abs/1906.02390v1>.
- [10] WANG Z C, LV Q S, LAN X H, et al. Cross-lingual knowledge graph alignment via graph convolutional networks[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018: 349-357.
- [11] SUN Z Q, WANG C M, HU W, et al. Knowledge graph alignment network with gated multi-hop neighborhood aggregation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 222-229.
- [12] WU Y T, LIU X, FENG Y S, et al. Relation-aware entity alignment for heterogeneous knowledge graphs[EB/OL]. (2019-08-22) [2025-03-12]. <https://arxiv.org/abs/1908.08210v1>.
- [13] ZHU Y, LIU H Z, WU Z H, et al. Relation-aware neighborhood matching model for entity alignment[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 4749-4756.
- [14] WU Y T, LIU X, FENG Y S, et al. Jointly learning entity and relation representations for entity alignment[EB/OL]. (2019-09-20) [2025-03-12]. <https://arxiv.org/abs/1909.09317v1>.
- [15] BIANCHINI M, GORI M, SCARSELLI F. Inside PageRank[J]. ACM Transactions on Internet Technology, 2005, 5(1): 92-128.
- [16] DEVLIN J, CHANG M W, LEE K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[EB/OL]. (2019-05-24) [2025-03-12]. <https://arxiv.org/abs/1810.04805v2>.
- [17] JIANG T T, BU C Y, ZHU Y, et al. Combining embedding-based and symbol-based methods for entity alignment[J]. Pattern Recognition, 2022, 124: 108433.
- [18] GAO J L, LIU X Y, CHEN Y B, et al. MHGCN: multi-view highway graph convolutional network for cross-lingual entity alignment[J]. Tsinghua Science and Technology, 2022, 27(4): 719-728.
- [19] SU Z H, XU T, DAI Y G, et al. Cross-lingual entity alignment method based on attribute weight updating network[J]. Journal of Northwestern Polytechnical University, 2024, 42(1): 157-164.
- [20] LIANG Y, CAI W S, YANG M H, et al. An unsupervised multi-view contrastive learning framework with attention-based reranking strategy for entity alignment[J]. Neural Networks, 2024, 179: 106583.
- [21] ZHU R B, MA M, WANG P. RAGA: relation-aware graph attention networks for global entity alignment[M]//Advances in Knowledge Discovery and Data Mining. Cham: Springer International Publishing, 2021: 501-513.

Multiple Information Graph Convolutional Network Entity Alignment Method

XU Zhenshun^{1,2}, ZHANG Wenhao^{1,2}, WANG Zhenbiao^{1,2}, TANG Zengjin^{1,2}, ZHAO Zeyu^{1,2}, SU Mengyao^{1,2}

(1. College of Compute Science and Engineering, North Minzu University, Yinchuan 750021, China; 2. The Key Laboratory of Images & Graphics Intelligent Processing of State Ethnic Affairs Commission, North Minzu University, Yinchuan 750021, China)

Abstract: Due to the heterogeneity in entity representation, relationship definition, and semantic structure between different knowledge graphs, it is difficult to effectively improve alignment quality in the presence of structural differences and information loss in the graphs by relying solely on graph structure. Therefore, in this study a graph conv-

olutional entity alignment method that integrates multiple information was proposed. Firstly, the improved PageRank algorithm was used to filter triplets and alleviate the impact of differences in knowledge graph structure. Next, we learn the embedding representations of entities and attributes were learnt through graph convolutional networks, and the relationships between entities were iteratively updated by using these representations. Finally, based on the PBAB method, text description information was integrated and weighted with graph structure information to enhance the effectiveness of entity alignment. The experimental results showed that the proposed method improved the Hits@1 metric by approximately 3% compared to the optimal baseline, with corresponding improvements observed in other evaluation metrics as well.

Keywords: knowledge graph; graph convolutional network; entity alignment; graph attention network; pre-trained languages model

(上接第 82 页)

Multimodal Modulation Recognition Method Based on BLR Parallel Structure

JIANG Hua, XIAO Kejie, HU Po, GONG Kexian, ZHAO Zhenyu

(School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: Aiming at the problem that existing convolutional neural network (CNN)-based modulation recognition methods are highly dependent on single modal data (e.g., IQ sequences) and difficult to adequately extract multi-dimensional features of signals, in this study a multimodal parallel structural modulation recognition method was proposed based on bidirectional long short-term memory network (BiLSTM) and residual network (ResNet), termed the BiLSTM-ResNet (BLR network). Firstly, the temporal features of IQ data were extracted by BiLSTM in the upper branch, and the spatial features of constellation maps were extracted by ResNet-18 in the lower branch. Secondly, serial feature fusion was used in the decision fusion module to better exploit the complementary nature of the multimodal data. Lastly, the signal modulation styles were recognised with the help of the model's feature extraction capability. In this study, experimental validation was carried out on the publicly available dataset RML2018.01a. The experimental results showed that the overall recognition accuracy of BLR network in the 6–30 dB SNR interval was stable at 96.48%, 2.61% and 3.91% higher than that of the single-modal ResNet and BiLSTM models, respectively, and 1.25% higher than that of the CNN-LSTM model with concatenated structure, which verified that the model proposed in this paper had the modulation recognition problem Effectiveness.

Keywords: automatic modulation recognition; convolutional neural network; multimodal; feature fusion; parallel structure